

引文格式:李家艺,黄昕,胡宇平,等.夜光影像和高分辨率影像耦合的土耳其Mw 7.8地震建筑倒塌智能解译[J].武汉大学学报(信息科学版),2023,48(10):1706-1714.DOI:10.13203/j.whugis20230275



Citation: LI Jiayi, HUANG Xin, HU Yuping, et al. Fusion of Optical Daily and Night-time Light Remote Sensing Images for Collapsed Building Detection: A Case in Turkey Mw 7.8 Earthquake[J]. Geomatics and Information Science of Wuhan University, 2023, 48(10):1706-1714.DOI:10.13203/j.whugis20230275

夜光影像和高分辨率影像耦合的土耳其 Mw 7.8 地震建筑倒塌智能解译

李家艺^{1,2} 黄 昕¹ 胡宇平¹ 张 震¹ 张雪婷¹
张淑蕾¹ 方 兴³

1 武汉大学遥感信息工程学院,湖北 武汉,430079

2 湖北珞珈实验室,湖北 武汉,430079

3 武汉大学测绘学院,湖北 武汉,430079

摘要:建筑倒塌检测是震后损失评估、紧急救援的重要内容。面向2023年土耳其Mw 7.8地震的紧急救援,综合利用卫星遥感能智能解译技术,耦合高空间分辨率卫星遥感影像和夜间灯光影像,以较低的时间和人力成本高效评估了土耳其Mw 7.8大地震中极灾区的建筑倒塌情况。设计了一种多层次的极灾区与倒塌建筑快速定位方案,首先利用中等分辨率夜光遥感数据确定极灾区,然后利用高分辨率光学遥感影像深度学习技术提取倒塌建筑。设计了一种半监督深度学习方案,只需要初始化人工采集少量倒塌建筑样本,就可以通过在训练中增广获取当地样本,增强深度网络的表征能力,最终实现定位坍塌房屋。监测到阿德亚曼-卡赫拉曼马拉什-安塔基亚一线的阿拉伯板块-欧亚板块交界地带的6个城市受灾严重。从极灾区中共检测出2 377栋倒塌建筑,除努尔达吉和安塔基亚市的倒塌建筑比例超过2%外,伊斯拉希耶、蒂尔克奥卢、卡赫拉曼马拉什和阿德亚曼市倒塌建筑比例均接近于1%,通过人工核查,智能解译方案的查全率为74%~93%,证明所提方案可以及时为震后紧急救援决策提供参考。

关键词:光学卫星遥感;夜光遥感;地震;倒塌建筑检测;深度学习;半监督学习

中图分类号:P237

文献标识码:A

收稿日期:2023-08-25

DOI:10.13203/j.whugis20230275

文章编号:1671-8860(2023)10-1706-09

Fusion of Optical Daily and Night-time Light Remote Sensing Images for Collapsed Building Detection: A Case in Turkey Mw 7.8 Earthquake

LI Jiayi^{1,2} HUANG Xin¹ HU Yuping¹ ZHANG Zhen¹ ZHANG Xueting¹
ZHANG Shulei¹ FANG Xing³

1 School of Remote Sensing and Information Engineering, Wuhan University, Wuhan 430079, China

2 Hubei Luojia Laboratory, Wuhan 430079, China

3 School of Geodesy and Geomatics, Wuhan University, Wuhan 430079, China

Abstract: Objectives: The Mw 7.8 earthquake occurred in Turkey on February 6th, 2023, which is a rare powerful earthquake in recent years. Building collapse detection is an important part of post-earthquake damage assessment and emergency rescue. Facing the emergency rescue and post-earthquake disaster assessment, this paper aims to comprehensively utilize the intelligent interpretation technology of satellite remote sensing, coupled with high-resolution optical daily and night-time light remote sensing images, and to efficiently assess the collapsed buildings in the extreme disaster areas with low time and labor costs. Methods: In this paper, we present a multi-level rapid localization scheme for disaster-affected regions. First, the proposed approach involves the utilization of low- and medium-resolution night-time light data to estimate

基金项目:国家自然科学基金(42071311,41971295,42271328)。

第一作者:李家艺,博士,副教授,主要从事多源遥感影像智能解译。zjjerica@whu.edu.cn

通讯作者:黄昕,博士,教授。xhuang@whu.edu.cn

the extent of extreme disaster areas. Subsequently, high-resolution optical remote sensing imagery is employed to extract the collapsed buildings. By training a semi-supervised deep learning network with a small number of manually collected samples, the scheme automatically identifies collapse areas, thereby facilitating the precise localization of collapsed buildings. A high-resolution architecture network, HRNet, is employed in this study. HRNet has the advantages in both semantic and spatial feature representation, and can capture the collapsed buildings with multi-scale characteristics. **Results:** Six cities along the border between the Arab Plate and the Eurasian Plate are severely affected, from Adelman to Kahraman Marash, and then to Antakia. A total of 2 377 collapsed buildings are detected in the extreme disaster areas. Except for Nurdaji and Antakia cities, where the proportion of collapsed buildings exceeded 2%, the proportion of collapsed buildings in the other four cities is close to 1%. After manual verification, the recall rate of the intelligent interpretation plan is between 74% and 93%. **Conclusions:** The efficiency and effectiveness of this approach are demonstrated through its application in assessing the building collapse situation after the Mw 7.8 earthquake in Turkey. The proposed work can serve as a timely reference for macro decision-making in post-earthquake emergency rescue operations.

Key words: optical satellite remote sensing; night-time light remote sensing; earthquake; collapsed building detection; deep learning; semi-supervised learning

地震特别是重大地震对人类社会的危害巨大,对地震影响的快速评估、应急响应成为研究热点。近年来已实现通过多星组网协同监测,辅助分析重大地震灾区主要损毁要素、次生灾害等的时空分布。建筑物作为主要的承灾体,其倒塌损害是造成人员伤亡和经济损失的主要原因之一。据统计,地震中 75% 以上的人员伤亡是由于建筑物的倒塌而引起的^[1]。因此,利用遥感智能解译技术探索与实现震后建筑倒塌快速检测是地震应急监测研究中的关键^[2]。

遥感可以快速、大范围地对损毁建筑进行监测,可为面向应急的地震损失综合评估提供支持。中国基于遥感数据解译灾情最早可以追溯到 1966 年邢台地震和 1976 年唐山地震。早期卫星遥感数据的空间分辨率不足,难以识别承灾体,此时航空影像(如机载多光谱数据)是主要支撑的数据源^[3],而解译技术以目视判读为主。机载遥感数据的优势在于数据获取平台相对灵活,缺点在于难以大范围采集。随着星载传感器的发展,多星组网和全球空间基础设施向体系化、全球化的趋势发展。目前国际上已建立多个政府间的遥感卫星共享网络和政府间公益减灾数据合作机制,在灾害情况下可以协调国外卫星,共享数据。面向应急响应,可以及时获取亚米级空间分辨率的数据,以支持对精细尺度的承灾体(如建筑)的检测。例如,在 2008 年汶川地震中,SPOT 系列、Quickbird 系列、WorldView 系列、RADARSAT 系列、ZY 系列、北京 1 号等 24 颗卫星、1 277 景影像^[4]被应用于交通道路破坏点位分

布、倒塌建筑物监测、滑坡和堰塞湖等次生灾害提取以及临时安置点监测任务^[5]。总的来讲,在震害信息提取方面,多源数据、智能提取是研究和应用的热点。

多源遥感数据根据观测的物理特性可以分为光学影像数据和合成孔径雷达(synthetic aperture radar, SAR)数据。前者的优点在于可用的高空间分辨率传感器更多,特征可视化对用户更加友好;缺点在于在恶劣气象条件下影像观测质量差。相比之下,SAR 数据的优势在于全天时、全天候的稳定观测,缺点在于数据信噪比低,受限于成像模式,导致目视效果不佳,因而常用于在恶劣气象条件下作为光学影像的补充。

从解译技术的角度来看,建筑物受损后会丧失原有的规则几何形态和纹理特征,在拥有震前震后多时序影像时可以采用变化检测技术^[6]。然而,由于震后影像成像条件复杂,多时序影像之间存在明显的地域差异,使得提取结果往往存在大量虚景,难以为快速应急响应提供支持^[7]。与此同时,考虑到数据的可获取性,当仅有震后单一时序的影像时,以倒塌建筑所表现出的不同色调的杂乱斑点状、倒塌部分在影像上呈暗色、照射光线呈漫反射等形式来设计特征,采用面向像元或者面向对象的影像分类技术,可在人工采集倒塌建筑样本的条件下提取受灾区建筑损毁信息^[8-9]。近年来,随着深度学习技术的发展,目前基于深度卷积神经网络应用于灾情智能化识别已有若干示例^[6-11]。但是现有方案往往依赖于大量样本采集,耗时且成本高。

2003-02-06凌晨,土耳其南部发生Mw 7.8大地震,造成了大量建筑物坍塌损毁。为了灾情评估和救援规划,需要通过遥感手段第一时间获取倒塌建筑的数量和方位。土耳其大地震发生后,为了迅速利用全球遥感卫星监测灾区,土耳其灾害和应急管理局于当地时间2月6日07:04要求启动《空间与重大灾害国际宪章》,以便于在灾害情况下可以协调国外卫星、共享数据。依托共享数据,微软在2月中旬发布了土耳其建筑损毁评估报告^[12],利用卫星影像和人工智能模型提取出3 849栋受损的建筑。然而,该报告只检测了离震源最近的4个城市,缺乏对其他极灾区的分析。本文首先利用中低分辨率夜间灯光数据快速获取极灾区范围,然后在极灾区用所提出的小样本深度学习技术在高分辨率影像上提取倒塌建筑,完成此次地震所涉城市的整体评估。

1 研究区概况及数据来源

1.1 研究区概况

20世纪80年代开始,土耳其的城镇化进程开始加速。基于全球不透水面数据(global impervious surface area, GISA)^[13]绘制土耳其卡赫拉曼马拉什省1985—2019年不透水面变化过程,如图1所示。不透水面指的是建筑、道路这种阻止水直接渗透的地表面,与城市扩张存在密切关系,对不透水面的监测和分析对于城市发展具有重要意义。通过对不透水面面积和分布的监测,可以更好地反映城市建筑扩张的速度和空间模式。由图1可以看出,1985—2019年,卡赫拉曼马拉什省不透水面的范围有明显的扩张。在城镇化快速发展的背景下,建筑不论是在城市规划还是在环境评估领域,都是非常重要的研究对象。

1.2 数据来源

1.2.1 夜间灯光数据

地震活动通常会导致灾害性破坏,包括断电和灯光熄灭等情况。利用夜间灯光数据(nighttime light, NTL)快速捕捉到这些由地震引起的变化。本文选择由美国的SNPP(Suomi national polar-orbiting partnership)卫星采集的VNP46A2产品,该数据空间分辨率为15"(约500 m),提供逐日全球夜间灯光。VNP46A2数据经过大气校正、地形校正以及月光BRDF(bidirectional reflectance distribution function)校正,消除月光、杂散光和季节性植被变化影响^[14]。考虑到云和阴影

的影响,选取2023-01-24和2023-02-28的影像,分析震前、震后夜间灯光辐射亮度差异。

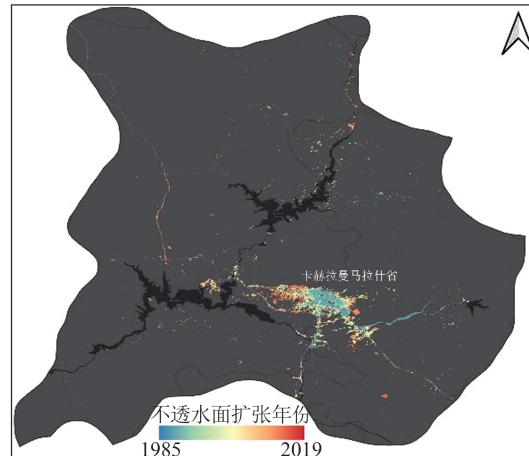


图1 1985—2019年土耳其卡赫拉曼马拉什省
不透水面扩张分布

Fig. 1 Urban Expansion Process of Kahramanmaraş,
Turkey from 1985 to 2019

1.2.2 高空间分辨率影像

Maxar 提供的2023-02-07—2023-02-28震后影像数据,空间分辨率约0.3 m,采用通用横轴墨卡托UTM投影,影像范围几乎完全覆盖了主要受损城市的地震区域。在处理过程中排除了云量较高的影像,并按照城市范围进行镶嵌和融合,得到各个城市完整的震后影像。

1.2.3 微软建筑数据集

本文所用的建筑开源数据集是微软在Bing地图上提取独栋建筑物所得。2015—2022年,微软在土耳其更新了1 300万栋建筑,为土耳其地震倒塌建筑的检测提供了丰富的参考数据。建筑标签以GeoJSON的格式在GitHub上开源发布(数据下载地址:<https://github.com/microsoft/GlobalMLBuildingFootprints>)。

2 多层次受灾区域快速定位

2.1 基于中低分辨率夜灯观测的极灾区范围估计

本文使用SNPP卫星获取的夜光遥感影像来确定主要受灾地区,选取了此次土耳其地震震前2023-01-24和震后2023-02-08的影像进行对比,2023-02-07的影像因为受云的影响太严重而未被采用。通过计算前后两期夜间灯光辐射亮度的差值来快速定位极灾区范围,灾后夜间灯光辐射亮度比灾前降低,且值越小则指示着受到灾害性破坏越强烈。首先利用夜间灯光数据找到受灾城市,在城市范围内统计夜光亮度总量,找到地震前后

变化最大的城市,然后在这些城市内部探测受地震影响剧烈的地区。具体地,将原始数据升级格网尺度到 45''(约 1 500 m),用每个格网内所有 NTL 数据的平均值求取夜间灯光变化量,以此减少数据误差。

2.2 基于高分辨率光学遥感的倒塌建筑提取

灾后卫星图像的每个像素最终都将被标记为倒塌建筑或背景(即不属于受损建筑的任何地物)。对每个感兴趣的区域,采集样本并逐像素地标记为上述两类。根据夜间灯光提取的极灾区范围提示,在 4 个城市的震后影像中共采集标注 224 个 512×512 像素的倒塌建筑样本用于训练,其中努尔达吉市 40 个,伊斯拉希耶市 45 个,特克格鲁市 47 个,卡赫拉曼马拉什市 92 个。

在上述少量的人工勾画样本基础上,采用半监督学习的方式训练深度卷积神经网络,使其能够自动检测出震后影像中的坍塌房屋。训练过程中采用了数据增强手段,包括随机旋转、翻转和尺度变化,工作流程如图 2 所示。

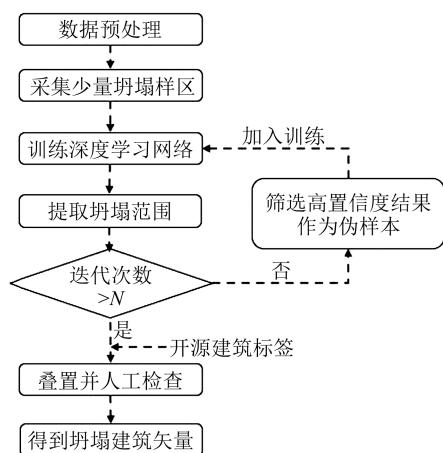


图 2 基于半监督学习的倒塌建筑提取流程图

Fig. 2 Semi-Supervised Collapsed Building Extraction Framework

将人工采集的少量样本输入到深度卷积神经网络 HRNet 中训练,本文采用 HRNet-V2-W48 网络,参数量为 $65.9 \text{ M}^{[15]}$ 。HRNet 通过将高低分辨率的卷积流分支并行连接,使得其能够保留高分辨率的特征图强化位置特征,从而学习到更为精确的空间特征表征。同时,该网络通过重复多分辨率融合,合理利用不同分辨率的特征表征,指导多尺度信息融合,从而不断强化语义信息。因此,在土耳其真实复杂场景下,相较于 DeepLab^[8] 和 Mask R-CNN^[10],该网络能够更为

精确有效地对目标较小的倒塌房屋进行定位和提取。HRNet 首先逐步提取出 4 种不同尺度的特征,然后拼接这些特征,最终预测影像上每一个像素是否属于坍塌区域。其中特征提取部分包含 4 条平行的路径,分别提取 4 种不同分辨率的特征。分辨率高的特征拥有更丰富的细节信息,如边缘、角点等,分辨率低的特征则拥有更丰富的全局特征,如类别、结构等,抽象层次更高。HRNet 并行地保留了细节特征,而且不同并行路径之间频繁地交换信息,让细节和全局特征充分融合。

虽然 HRNet 具有强大的解译能力,但受限于坍塌区域样本数量不足,使用传统监督学习方式训练将难以得到准确的预测结果。本文采用了半监督学习的方式,流程如图 3 所示。首先将人工采集的少量样本输入到网络中训练,然后用训练后的网络对整个受灾区域做初步预测,其中置信度大于 0.99 的预测结果可作为伪标签,与对应的影像一起加入到新一轮的网络训练中。由于训练样本的增加,网络可以得到更准确的坍塌区域,又可以增加新的伪样本,如此反复迭代直到迭代次数满足条件,输出最终的提取结果。

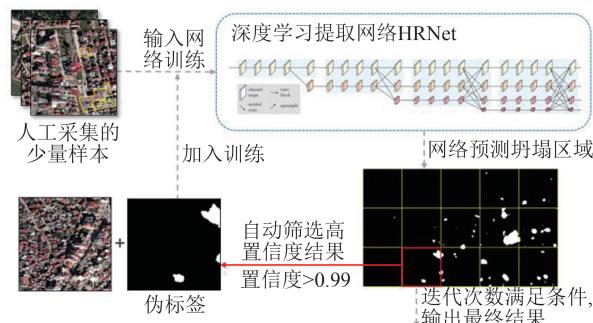


图 3 基于 HRNet 的半监督训练示意图

Fig. 3 Semi-Supervised Training Approach of HRNet

在 HRNet 提取震后影像上坍塌区域像素级结果的基础上,利用震前的建筑开源数据集来定位对象级倒塌建筑。选取受灾区域的微软建筑标签,将其与坍塌区域预测图叠置,将坍塌范围内的建筑标记为倒塌建筑。但由于坍塌区域中的沙石无规则地散落在建筑周边,影像上坍塌区域的范围往往比真实发生坍塌的建筑范围大,HRNet 检测所得坍塌区域的中间和边缘都可能存在一些没有发生坍塌的建筑。对此,面向精准定位和紧急救援的需求,采用人工检查做少量的删减和补充,得到最终的倒塌建筑矢量,如图 4 所示。

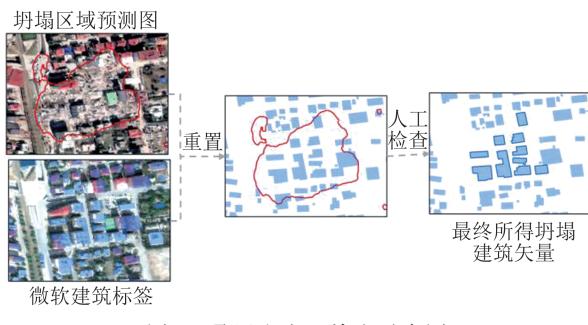


图4 叠置和人工检查示意图

Fig. 4 Overlay and Manual Inspection

3 地震建筑倒塌检测结果与讨论

3.1 城市尺度的NTL变化情况

本文对比了土耳其多个城市震前、震后的夜间灯光数据,结果如图5所示。由图5可以看出,NTL下降幅度较大的城市都集中在阿德亚曼-卡赫拉曼马拉什-安塔基亚一线的阿拉伯板块-欧亚板块交界地带。其中,受灾最严重的安塔基亚市夜光下降的比例甚至超过80%。对此,选择板块交界带上的阿德亚曼、卡赫拉

曼马拉什、蒂尔克奥卢、努尔达吉、伊斯拉希耶、安塔基亚6个城市(见图5(a)、5(b)中红色圆圈),在夜间灯光提取的主要受灾地区人工勾画少量标注,用于精细的倒塌建筑语义分割。

3.2 倒塌建筑评估结果

从极灾区中总共检测出2 377栋倒塌建筑,每个城市的整体检测效果如图6所示,其中红色区域表示检测的倒塌建筑。每个城市的局部示例如图7所示,包括震前影像、震后影像中深度学习网络预测的坍塌范围和最终输出的倒塌建筑矢量图。由图7可以看出,阿德亚曼和卡赫拉曼马拉什的建筑分布较为密集,存在建筑成片倒塌的情况,且有很多高层建筑倒塌;安塔基亚建筑倒塌的特点与之相似,情况更为严重;蒂尔克奥卢和伊斯拉希耶倒塌的建筑较少,且一般都是独栋的建筑,分布稀疏;受灾最严重的努尔达吉虽然震后影像质量不佳,但深度学习网络仍然能够较为准确地提取出坍塌废墟所在的范围。

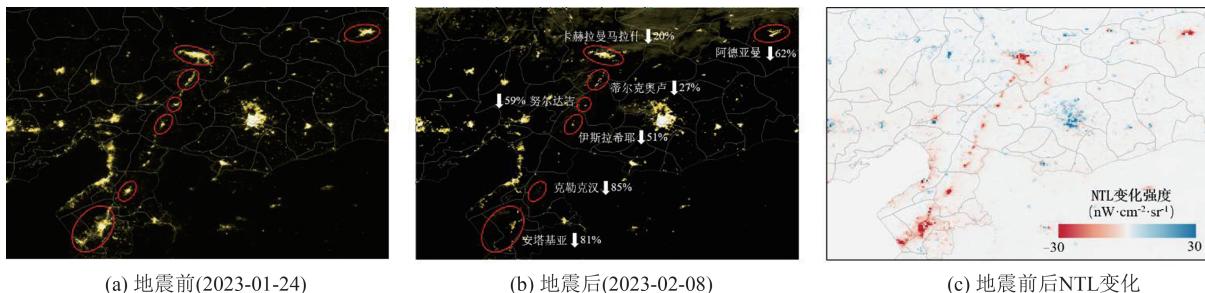


图5 城市尺度下地震前后夜光图及NTL变化强度图

Fig. 5 NTL Images and Intensity Map of NTL Change Before and After Earthquake at City Scale

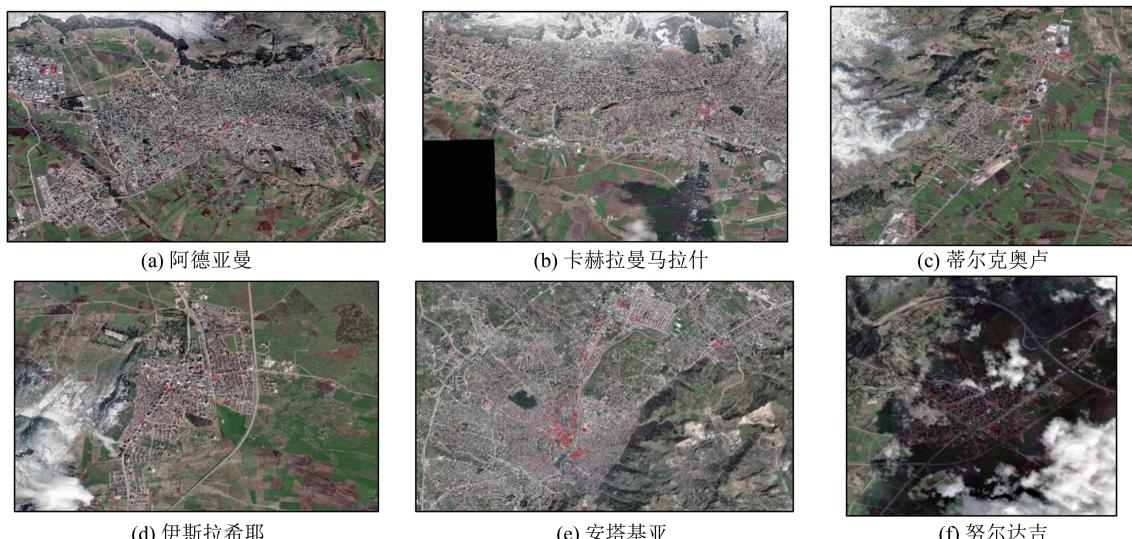


图6 主要受灾城市倒塌建筑分布图

Fig. 6 Distribution Map of Collapsed Buildings in Major Affected Cities

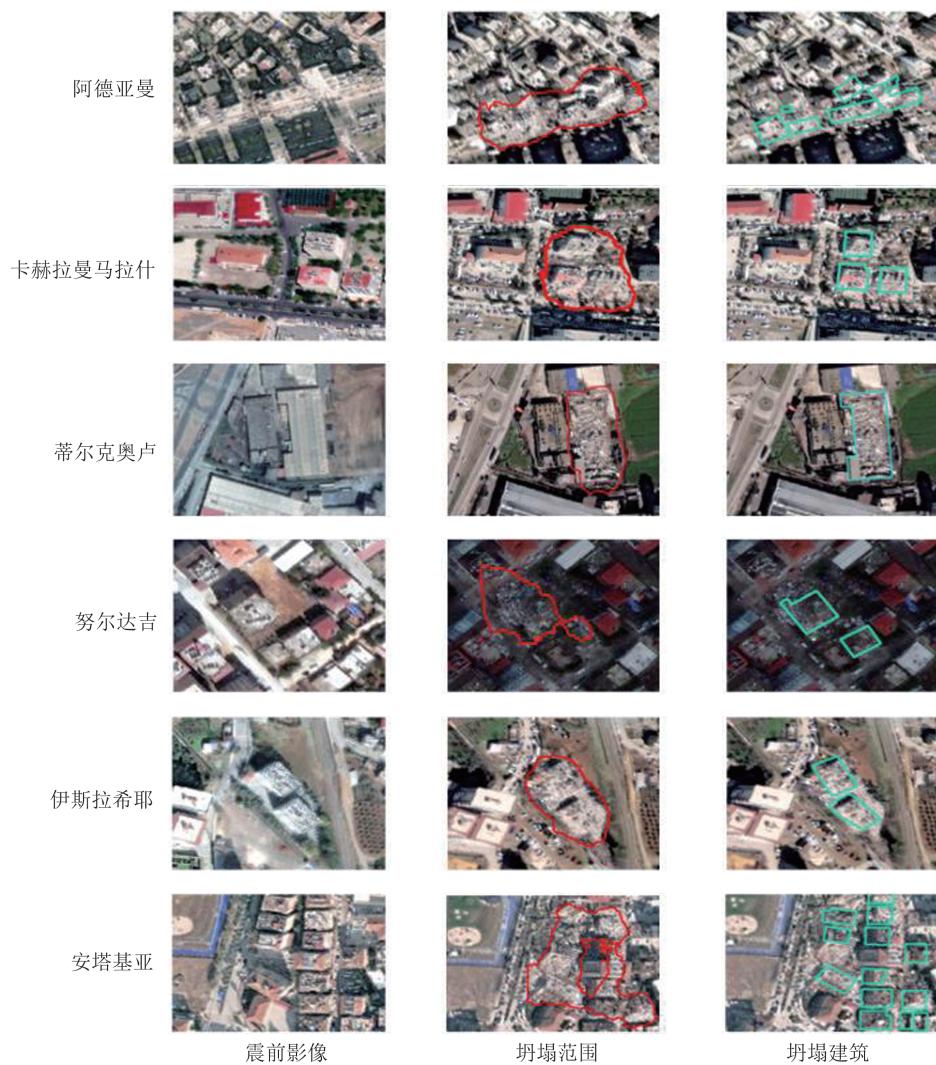


图7 主要受灾城市倒塌建筑局部示例

Fig. 7 Details of Collapsed Buildings in Major Affected Cities

不同城市的倒塌建筑数目和比例见表1。总体而言,努尔达吉虽然是震前建筑数量最少的城市,但坍塌情况最严重,倒塌建筑占比达到5.85%,数量上接近于阿德亚曼这类大型城市。在建筑数目过万的大型城市中,安塔基亚的建筑坍塌比例最高,超过1 000栋建筑坍塌。除努尔达吉和安塔基亚的倒塌建筑比例超过2%外,其

余4个城市倒塌建筑比例都接近于1%。

为了分析本文深度学习网络预测建筑物倒塌的自动化水平,分别统计网络预测和人工检查补充的倒塌建筑数目,并计算查全率。表1中的结果显示,所有城市的查全率都超过了74%,最高达到了93%,说明本文的深度学习方法可以代替大部分人工检查方法,具有较高效率。

表1 极灾区建筑倒塌情况及深度学习网络预测自动化程度

Tab. 1 Collapsed Buildings in Extreme Disaster Area and Prediction Automation Degree of Deep Learning Network

城市	震前建筑数目	倒塌建筑数目	倒塌比例/%	网络预测的倒塌建筑数目	人工检查补充倒塌建筑数目	查全率/%
阿德亚曼	25 550	275	1.08	222	53	80.73
卡赫拉曼马拉什	41 317	557	1.35	476	81	85.46
蒂尔克奥卢	8 070	73	0.90	68	5	93.15
努尔达吉	4 631	271	5.85	215	56	79.34
伊斯拉希耶	7 215	95	1.32	71	24	74.74
安塔基亚	44 898	1 106	2.46	904	202	81.74

3.3 与微软结果对比

微软在2023年2月中旬发布的土耳其建筑损毁评估报告分析了卡赫拉曼马拉什、蒂尔克奥卢、努尔达吉、伊斯拉希耶4个城市的建筑受损情况,结果见表2。

表2 微软发布的主要受灾城市建筑受损情况统计表
Tab. 2 Statistics of Damaged Buildings in Four Major Affected Cities Released by Microsoft

城市	震前建筑数目	受损建筑数目	受损比例/%
卡赫拉曼马拉什	40 375	3 005	7.44
蒂尔克奥卢	3 816	185	4.85
努尔达吉	4 537	331	7.30
伊斯拉希耶	13 215	328	2.48

需要注意的是,本文工作与微软发布的结果相比有以下差别:

1)检测对象不同。本文提取的倒塌建筑不包括轻微受损的建筑,而微软提取的是所有受损建筑,因此数量更多,受损比例也比坍塌比例更高。

2)检测范围不同。单个城市震前建筑数目存在差异,因为微软检测范围由行政区划界定,而本文的检测范围由待检测影像所在范围界定。

3)确定极灾区的方式不同。微软主要检测了靠近震中的4个受灾城市,本文不仅考虑距离因素,还结合夜光遥感,增加了板块交界地带上的安塔基亚市和阿德亚曼市。这两个城市NTL下降幅度都超过60%,虽然离震中更远,但受灾情况却很严重。从最终的结果来看,两个城市的倒塌建筑比例都比较高,尤其是安塔基亚市,在6个城市中坍塌比例排名第2。

将微软在报告中展示的4个城市的局部示例与本文的检测结果进行对比,如图8所示,其中黄色方框指示了本文和微软的结果有所不同的区域。微软将这些区域中的建筑判定为受损,但目视对比震前震后影像难以看到明显的区别,说明其并未达到倒塌的受损级别,在本文结果被检测为未倒塌建筑。从结果可用性的角度中,提取倒塌建筑能够更直接地反映灾害最严重的区域,更具指导意义。

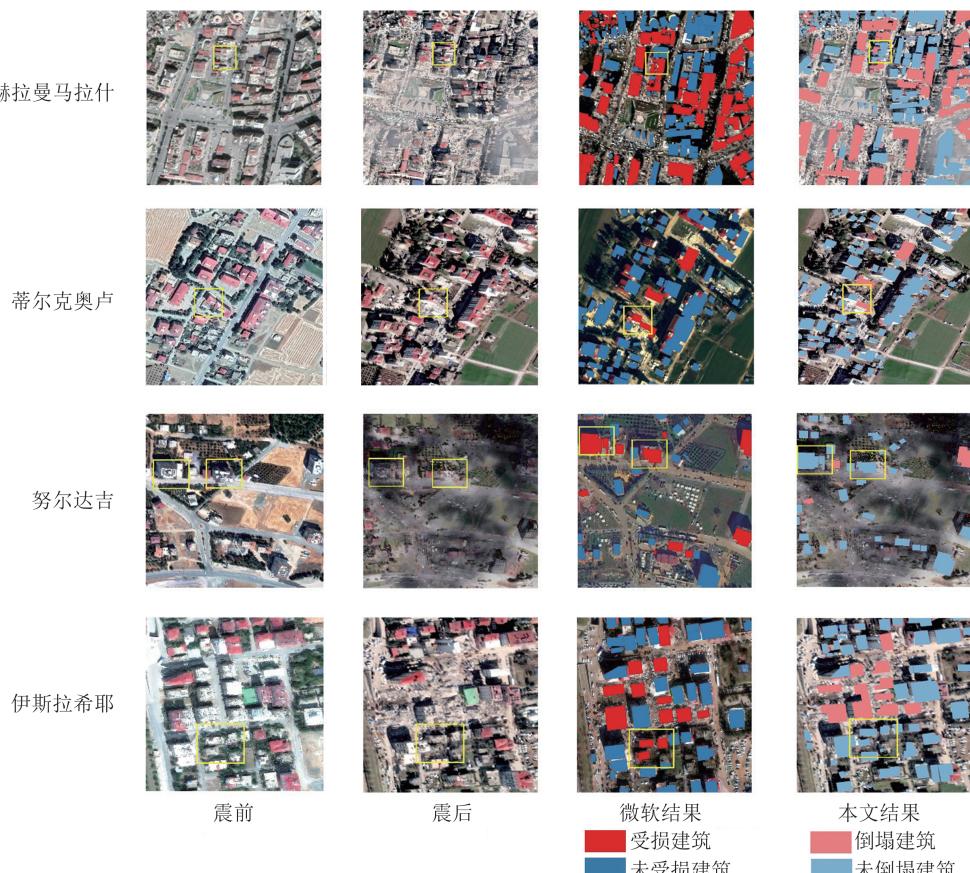


图8 本文提取的倒塌建筑和微软结果对比

Fig. 8 Comparison of Collapsed Buildings and Damaged Buildings Released by Microsoft

3.4 处理效率分析

本文工作涉及 5 人团队,采用 5 台服务器,每个服务器上搭载 1 个 24 GB 的 NVIDIA GeForce RTX 3090 GPU。样本采集由 1 人完成,耗时 2~3 h。单个城市的网络训练时间约为 1.5 h,人工检查所需时间受到建筑总量和网络预测效果的影响,最慢 0.5 d 内可以完成。由于不同城市的网络训练和人工检查工作可以同步进行,6 个城市的所有检测工作在两天内完成,控制在地震灾害的黄金救援时间以内。

4 结语

遥感技术可以对震后灾区受灾场景进行大范围观测,持续地为震后应急响应提供数据支持。本文基于多源光学卫星遥感数据建立了一套多层次的受灾区域快速定位方案,高效评估了土耳其 Mw 7.8 大地震中主要受灾区域的建筑倒塌情况。首先利用中低分辨率夜灯观测数据估计极灾区范围,再基于高分辨率光学遥感影像提取受灾建筑。受灾建筑提取流程高度自动化,只需要人工采集少量的坍塌区域样本,就可以通过半监督的方式训练深度学习网络,使其能够快速识别震后影像中的坍塌区域。结合开源建筑标签,进一步定位倒塌建筑,得到对象级的提取结果。本文从定位的 6 个极灾区中共检测出 2 377 栋倒塌建筑,其中努尔达吉、安塔基亚的建筑坍塌比例分别达到 5.85% 和 2.46%,受灾情况最为严重,另外 4 个极灾区阿德亚曼、卡赫拉曼马拉什、蒂尔克奥卢、伊斯拉希耶的建筑坍塌比例均接近于 1%。整套方案时间人力成本低,可以及时为震后紧急救援的宏观决策提供参考。

参 考 文 献

- [1] Tian Lili. Analysis of Factors Affecting Casualties in Earthquake Disasters and Estimation Formulas for Casualties [D]. Beijing: Capital University of Economics and Trade, 2012. (田丽莉. 地震灾害人员伤亡影响因素分析及人员伤亡估算公式[D]. 北京:首都经济贸易大学, 2012.)
- [2] Sui Haigang, Liu Chaoxian, Huang Lihong, et al. Application of Remote Sensing Technology in Earthquake-Induced Building Damage Detection[J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(7): 1008~1019. (眭海刚, 刘超贤, 黄立洪, 等. 遥感技术在震后建筑物损毁检测中的应用[J]. 武汉大学学报(信息科学版), 2019, 44(7): 1008~1019.)
- [3] Chen Xinlian. Quick Evaluation and Decision-making for Earthquake Disaster by Airborne Remote Sensing Information [M]. Beijing: Science Press, 1995. (陈鑫连. 地震灾害的航空遥感信息快速评估与救灾决策[M]. 北京: 科学出版社, 1995.)
- [4] He Haixia, Wu Bin, Li Ru, et al. Research on Requirements and Strategies of Satellite Cooperative Observation for Natural Disaster Emergency Response[J]. *Spacecraft Recovery & Remote Sensing*, 2018, 39(6): 91~101. (和海霞, 武斌, 李儒, 等. 面向自然灾害应急的卫星协同观测策略研究[J]. 航天返回与遥感, 2018, 39(6): 91~101.)
- [5] Li Suju, Liu Ming. Application of Satellite Remote Sensing in Emergency Monitoring of Major Earthquake Disaster in China [J]. *City and Disaster Reduction*, 2018(4): 7~10. (李素菊, 刘明. 卫星遥感在我国重大地震灾害应急监测中的应用[J]. 城市与减灾, 2018(4): 7~10.)
- [6] Ye Xin, Qin Qiming, Wang Jun, et al. Detecting Damaged Buildings Caused by Earthquake from Remote Sensing Image Using Local Spatial Statistics Method [J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(1): 125~131. (叶昕, 秦其明, 王俊, 等. 利用高分辨率光学遥感图像检测震害损毁建筑物[J]. 武汉大学学报(信息科学版), 2019, 44(1): 125~131.)
- [7] Shi Mengyuan. Research on Building Seismic Damage Detection Method Based on Deep Learning [D]. Xi'an: Xi'an Technological University, 2023. (史梦圆. 基于深度学习的建筑物震害检测方法研究[D]. 西安: 西安工业大学, 2023.)
- [8] Ma Haojie, Research on Extracting Building Damage Information from Postearthquake Remote Sensing Images Based on Deep Learning [D]. Beijing: University of Chinese Academy of Sciences, 2020. (马豪杰. 基于深度学习的震后遥感影像建筑物损毁信息提取研究[D]. 北京: 中国科学院大学, 2020.)
- [9] Wu Luyuan, Tong Jingbo, Wang Zifa, et al. Classification of Damaged Grade on Rural Houses After Flood Disaster Based on Deep Convolutional Neural Network and Transfer Learning[J]. *Earth Science*, 2023, 48(5): 1742~1754. (吴禄源, 全敬博, 王自法, 等. 基于深度卷积神经网络和迁移学习的农村房屋洪涝灾害后受损等级分类[J]. 地球科学, 2023, 48(5): 1742~1754.)
- [10] Sui Haigang, Huang Lihong, Liu Chaoxian. Detecting Building Facade Damage Caused by Earth-

- quake Using CBAM-improved Mask R-CNN [J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(11): 1660–1668. (眭海刚, 黄立洪, 刘超贤. 利用具有注意力的Mask R-CNN检测震害建筑物立面损毁[J]. 武汉大学学报(信息科学版), 2020, 45(11): 1660–1668.)
- [11] Mouloud H, Chaker A, Nassim H, et al. Post-earthquake Damage Classification and Assessment: Case Study of the Residential Buildings After the $M_w = 5$ Earthquake in Mila City, Northeast Algeria on August 7, 2020 [J]. *Bulletin of Earthquake Engineering*, 2023, 21(2): 849–891.
- [12] Robinson C, Gupta R, Nsutezo S F, et al. Turkey Earthquake Report [R]. New York: Microsoft, 2023.
- [13] Huang Xin, Li Jiayi, Yang Jie, et al. 30 m Global Impervious Surface Area Dynamics and Urban Expansion Pattern Observed by Landsat Satellites: From 1972 to 2019 [J]. *Scientia Sinica (Terra)*, 2021, 51(11): 1894–1906. (黄昕, 李家艺, 杨杰, 等. Landsat卫星观测下的30m全球不透水面年度动态与城市扩张模式(1972—2019)[J]. 中国科学: 地球科学, 2021, 51(11): 1894–1906.)
- [14] Román M O, Wang Z S, Sun Q S, et al. NASA's Black Marble Nighttime Lights Product Suite [J]. *Remote Sensing of Environment*, 2018, 210: 113–143.
- [15] Sun K, Xiao B, Liu D, et al. Deep High-Resolution Representation Learning for Human Pose Estimation [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, USA, 2019.